Как подключить к Apache Spark проприетарный источник данных: теория, практика, грабли, костыли

Александра Белоусова Яндекс.Go





О чём я буду говорить

- Мотивация и постановка задачи
- Быстрое и простое решение
- Сложное производительное решение
- Грабли и костыли

Что надо было сделать?


YT

- Data Storage
- Scheduler
- Map Reduce

YT

- Миллион ядер
- Эксбибайт (ЕіВ) диска
- Около 10 тысяч пользователей

• И это только на одном кластере!



Spark + YT

- Запустить на ресурсах кластера ҮТ
- Читать данные из ҮТ
- Писать данные в ҮТ

• Показать wall time и cpu time лучше, чем у существующих решений

ҮТ – файловая система

/ |---> | tmp |---> | file.txt |---> | dataset_1 |----> | part-0.parquet |----> | part-1.parquet |----> | part-2.parquet |----> | part-0.parquet

|----> | part-1.parquet

```
YT
|---> | tmp
      |---> | file.txt
      |---> | example
                 |----> | example_table_1
                 |----> | example_table_2
```

Таблица в ҮТ

User level

#	а	b	С
0	"cat"	true	1
1	"dog"	true	20
2	"otter"	false	350

Attributes:

schema

a - String

b - Boolean

c - Integer

rowCount

Storage level

Columnar chunk 1

rows 0 - 200

Columnar chunk 2

rows 201 - 400

Columnar chunk 3

rows 401 - 600

Attributes:

schema

a - String

b - Boolean

c - Integer

rowCount




Простое решение: чтение

Дисклеймер


• API – набор классов / интерфейсов / методов, которые мы вызываем

• SPI – набор классов / интерфейсов / методов, которые мы расширяем или реализуем


Spark SPI




Spark SPI




Получение схемы




Получение партиций




Чтение партиции




Как это выполняется







Получение схемы




Получение партиций




Чтение партиции




Как это выполняется




Как это выглядит в коде




YT API



SPYT



Получение схемы



Преобразование схемы в StructType

```
{
    "a": "int32",
    "b": "string",
    "c": "uint64",
    "d": "any",
    "name.with.dots": "double",
}
```

Простые типы

Дополнительные типы

```
StructType (
    "a": "int32",
    "b": "string",
    "c": "uint64",
    "d": "any",
    "name.with.dots": "double",
}
StructType (
    SF("a", IntegerType),
    SF("b", StringType),
    SF("c", StringType,
    +original type in meta)
}
```

Подсказки для типов

```
"a": "int32",
  "b": "string",
  "c": "uint64",
  "d": "any",
  "name.with.dots": "double",
+ schema_hint
"d": ArrayType(StringType)
```


```
StructType (
  SF("a", IntegerType),
  SF("b", StringType),
  SF("c", StringType, +meta)
  SF("d", ArrayType(StringType)),
```

Переименование

```
{
    "a": "int32",
    "b": "string",
    "c": "uint64",
    "d": "any",
    "name.with.dots": "double",
}
```

```
StructType (
  SF("a", IntegerType),
  SF("b", StringType),
  SF("c", StringType, +meta)
  SF("d", ArrayType(StringType)),
  SF("name_with_dots",
      DoubleType,
      + original name in meta)
```

Получение схемы



Получение партиций




Таблица в ҮТ

User level

#	а	b	С
0	"cat"	true	1
1	"dog"	true	20
2	"otter"	false	350

Attributes:

schema

a - String

b - Boolean

c - Integer

rowCount

Storage level

Columnar chunk 1

rows 0 - 200

Columnar chunk 2

rows 201 - 400

Columnar chunk 3

rows 401 - 600

Attributes:

schema

a - String

b - Boolean

c - Integer

rowCount




Разбиение таблицы на партиции


- Можем узнать точное количество строк в таблице из метаданных
- Можем запрашивать диапазоны строк при чтении

• Бывают проблемы с равномерностью распределения

Получение партиций




Чтение партиции



Чтение партиции из YT


- API отдаёт строки таблицы в своём формате YtRow
- Нужно преобразовывать строки в спарковый Row
- В этот момент нужно сделать преобразование значений под спарковую систему типов

Чтение




Простое решение: запись


YT API




Spark SPI




Spark SPI





SPYT







Подготовка записи






Запись партиций







Подготовка таблицы




Запись партиций




Как это выполняется



Как это выглядит в коде





Особенности записи

- Обратное преобразование схемы
- Обратное преобразование строчек таблицы
- Meтод writeRows будет вызываться параллельно с разных экзекьюторов

Итог простого решения

• Чтение:

- Запрос схемы с драйвера
- Разделение на партиции на драйвере
- Чтение партиции на экзекьюторе

• Запись:

- Создание таблицы на драйвере
- Запись партиций с экзекьюторов параллельно

Подробное выступление Jacek Laskowski: https://www.youtube.com/watch?v=vfd83ELIMfc

Что не так с простым подходом?

Что не так с простым подходом

• Нет чтения батчами

Таблица в ҮТ

User level

#	а	b	С
0	"cat"	true	1
1	"dog"	true	20
2	"otter"	false	350

Attributes:

schema

a - String

b - Boolean

c - Integer

rowCount

Storage level

Columnar chunk 1

rows 0 - 200

Columnar chunk 2

rows 201 - 400

Columnar chunk 3

rows 401 - 600

Attributes:

schema

a - String

b - Boolean

c - Integer

rowCount



Батчи в YT

Storage level

Columnar chunk 1	Chunk meta
rows 0 - 200	200 rows a - ["alpaca", "cat"]
Columnar chunk 2	Chunk meta
rows 201 - 400	200 rows a - ["dog","mongoose"]
Columnar chunk 3	Chunk meta
rows 401 - 600	200 rows a - ["otter","zebra"]

Attributes:

schema

a - String


b - Boolean


c - Integer


rowCount


...


Батчи в Spark























Почему плохо читать построчно

• Не даём спарку использовать метаданные батчей

• Тратим CPU на перекладку из поколоночного формата в построчный

Что не так с простым подходом

- Нет чтения батчами
- Нельзя прочитать директорию целиком

ҮТ – файловая система

|---> **|** dataset 2

|----> | part-1.parquet |----> | part-2.parquet

|----> | part-0.parquet | part-1.parquet

```
YT
|---> | tmp
      |---> | file.txt
      |---> | example
                 |----> | example_table_1
                 |----> | example_table_2
```

Чтение директории из HDFS

```
/
|---> | tmp
|---> | file.txt
|---> | example
|----> | part-0.parquet
|----> | part-1.parquet
|----> | part-2.parquet
|----> | part-0.parquet
|----> | part-1.parquet
|----> | part-1.parquet
```

```
/
|---> | tmp
|---> | file.txt
|---> | example
|----> | example_table_1
|----> | example_table_2
```

spark.read.parquet("/tmp/example")


Чтение директории из YT

```
HDFS
 |---> | tmp
      |---> | file.txt
      --->  axample
              |---> | dataset 1
                      |----> ■ part-1.parquet
                      |----> | part-2.parquet
              |---> | dataset 2
                      |----> | part-0.parquet
                      |----> | part-1.parquet
     spark.read.parquet("/tmp/example")
```

```
/
|---> | tmp
|---> | file.txt
|---> | example
|----> | example_table_1
|----> | example_table_2
```

spark.read.yt("/tmp/example")


Partition discovery



spark.read.parquet("/tmp/example")

а		year
cat	••	2020
dog	3	2020
otter		2021

Partition discovery



Чего мы хотим от нового подхода

- Научиться читать поколоночными батчами
- Переиспользовать код, написанный для HDFS и Parquet:
 - Partition discovery
 - Обход директорий на чтении
 - Создание / удаление временных файлов на записи

Новое решение


Как Spark читает Parquet c HDFS

Разделение DataSource на две части


• Данные лежат в файловой системе (например, HDFS)

• Данные сохранены в каком-то формате (например, Parquet)


FileSystem




Статус файла




Статус директории




Файл не существует




Листинг директории




FileSystem




FileFormat




FileFormat




Чтение с HDFS




Листинг директории




Чтение схемы




Чтение партиции




Сравнение с простым подходом






Файл = партиция




Как это выполняется



Как SPYT читает таблицы с YT

YtFileSystem



Листинг директории







Таблица = директория




Псевдолистинг таблицы




Разбиваем таблицу на партиции




Читаем схему




Читаем отдельные партиции




Построчное чтение



Чтение батчами



ColumnarBatch



Как Spark пишет Parquet в HDFS


Запись в Parquet на HDFS

```
df.write.parquet("/tmp/example/dataset_1")
```


Создаём временную директорию

```
Phase 1
l->  tmp
   |---> | example
         |---> | dataset_1
              I--> ■ _temporary
```


Пишем файлы во временную директорию




Перемещаем файлы




Создаём временную директорию




Пишем файлы во временную директорию



Перемещаем файлы



FileFormat




```
/
|-> | tmp
|---> | example
|---> | dataset_1
|--> | _temporary
```

```
/
|-> tmp
|---> ataset_1
|--> temporary
|---> part-0.parquet
|---> part-1.parquet
|---> part-2.parquet
```

```
/
|-> tmp
|---> example
|---> dataset_1
|--> part-0.parquet
|--> part-1.parquet
|--> part-2.parquet
|--> tmp
```



FileCommitProtocol




```
/
|-> | tmp
|---> | example
|---> | dataset_1
|--> | _temporary
```

```
/
|-> tmp
|---> dataset_1
|--> tmp
|---> dataset_1
|--> part-0.parquet
|---> part-1.parquet
|---> part-2.parquet
```




Эмулируем транзакции в HDFS




Как SPYT пишет таблицы в YT

В ҮТ уже есть транзакции!



Запись партиций в ҮТ




Итоги продвинутого подхода


- Научиться читать поколоночными батчами
- Переиспользовать код, написанный для HDFS и Parquet:
 - Partition discovery
 - Обход директорий на чтении
 - Создание / удаление временных файлов на записи

Дополнительные фичи


FileSystem



Создание файлов в ҮТ



Чтение файлов из YT




Для чего это?

• Заработало скачивание файлов из YT в spark-submit


• Есть возможность сохранять event log в YT и читать его в SparkHistoryServer

Грабли и костыли


Листинг таблицы при чтении




Листинг таблицы делает драйвер





Читаем /tmp/example целиком







Читаем /tmp/example целиком







Однопоточный листинг партиций













Читаем /tmp/example целиком







Параллельный листинг на экзекьюторах







Parallel partition discovery










Реализация FileSystem



listStatus вызывается на экзекьюторе

listStatus вызывается на экзекьюторе



На экзекьюторе получаем Array[YtFileStatus]

listStatus вызывается на экзекьюторе



На экзекьюторе получаем Array[YtFileStatus]



Сериализуем и отправляем на драйвер

listStatus вызывается на экзекьюторе



На экзекьюторе получаем Array[YtFileStatus]



Сериализуем и отправляем на драйвер



Десериализуем на драйвере

listStatus вызывается на экзекьюторе

 \downarrow

На экзекьюторе получаем Array[YtFileStatus]



Сериализуем и отправляем на драйвер



Десериализуем на драйвере



Array[FileStatus]



Что делать?

• Учитывать, что методы для листинга директории могут вызываться на экзекьюторах

• Не пытаться обмануть SPI и использовать FileStatus

FileSystem – синглтон?

Использую синглтон в init / close

```
class YtFileSystem extends FileSystem {
 override def initialize (...): Unit = {
   initYtClient()
  override def close(): Unit = {
    closeYtClient()
```

Как устроен кэш FileSystem

```
private FileSystem getInternal (Key key, ...) {
     synchronized (this) {
           fs = map.qet(key);
     if (fs != null) return fs;
     fs = createFileSystem(uri, conf);
     synchronized (this) {
                                                     // refetch the lock again
           FileSystem oldfs = map.get(key);

if (oldfs != null) { // FS created while lock is releasing fs.close(); // close the new file system return oldfs; // return the old file system
           return fs;
```

Пытаемся взять FS из кэша

```
private FileSystem getInternal (Key key, ...) {
   synchronized (this) {
      fs = map.get(key);
   if (fs != null) return fs;
   fs = createFileSystem(uri, conf);
   synchronized (this) {
                             // refetch the lock again
     return fs;
```

Создаём новый инстанс FS

```
private FileSystem getInternal (Key key, ...) {
     synchronized (this) {
           fs = map.qet(key);
     if (fs != null) return fs;
     fs = createFileSystem(uri, conf);
     synchronized (this) {
                                                     // refetch the lock again
           FileSystem oldfs = map.get(key);

if (oldfs != null) { // FS created while lock is releasing fs.close(); // close the new file system return oldfs; // return the old file system
           return fs;
```

Другой поток создал инстанс раньше

```
private FileSystem getInternal (Key key, ...) {
     synchronized (this) {
           fs = map.qet(key);
     if (fs != null) return fs;
     fs = createFileSystem(uri, conf);
     synchronized (this) {
                                                    // refetch the lock again
           FileSystem oldfs = map.get(key);
if (oldfs != null) { // FS created while lock is releasing fs.close(); // close the new file system return oldfs; // return the old file system
           return fs;
```

Закрываем свой инстанс

```
private FileSystem getInternal (Key key, ...) {
   synchronized (this) {
      fs = map.qet(key);
   if (fs != null) return fs;
   fs = createFileSystem(uri, conf);
   synchronized (this) {
                             // refetch the lock again
     return fs;
```

Что делать?

• Запомнить, что FileSystem может быть создан не один, а лишний сразу будет закрыт

• Не использовать настоящие синглтоны в коде FileSystem

Кастомные параметры в Spark

• Большую часть параметров подключения можно прокидывать через конфиг спарка:

```
--conf spark.my.param=value
```

• Их удобно доставать из SparkConf, можно определять дефолтные значения в spark-defaults.conf

• Но они видны в логах и на вкладке Environment в Spark UI

Как скрыть отображение секретных параметров?

• В Spark есть специальный конфиг

spark.redaction.regex

• Все параметры, названия которых соответствуют регулярке, будут скрыты звёздочками

Как скрыть отображение секретных параметров?

• В Spark есть специальный конфиг

spark.redaction.regex

• Все параметры, названия которых соответствуют регулярке, будут скрыты звёздочками

• Или нет?

Что я сделала

• Прокинула параметр

spark.yt.token=token

• Сказала спарку, что он секретный

spark.redaction.regex=(?i)secret|password|token

✓ Параметр скрыт в SparkUI

Но в логах драйвера...

• Запуск в Spark Standalone логирует строку запуска драйвера полностью

```
Launch Command: "java" "-cp"
"-Dspark.yt.token=token" ...
org.apache.spark.deploy.worker.DriverWrapper ...
```

- ✓ Параметр скрыт в SparkUI
- 🗙 Параметр виден в логах драйвера

Что делать?

• B Spark 3.0 это починили

```
Launch Command: "java" "-cp"
"-Dspark.yt.token=*******(redacted)" ...
org.apache.spark.deploy.worker.DriverWrapper ...
```

- ✓ Параметр скрыт в SparkUI
- ✓ Параметр скрыт в логах драйвера

Но в списке процессов...

• На хосте, где запущен spark-submit, видны все его аргументы

```
> ps aux | grep spark
spark-submit ... --conf spark.yt.token=token ...
```

Может, обойти spark-submit?

• Всё равно придём к запуску класса SparkSubmit

```
> ps aux | grep spark

java -cp ... org.apache.spark.deploy.SparkSubmit
   --conf spark.yt.token=token ...
```

- ✓ Параметр скрыт в SparkUI
- Параметр скрыт в логах драйвера
- X Параметр виден в ps на хосте запуска spark-submit

Что делать?

• Костыль в SparkSubmit.scala

```
sys.env.get("SPARK_YT_TOKEN").foreach {
   token =>
     sparkConf.set("spark.yt.token", token)
}
```

- ✓ Параметр скрыт в SparkUI
- Параметр скрыт в логах драйвера
- ✓ Параметр скрыт в ps на хосте запуска spark-submit

Но в списке процессов в PySpark...

• Пользователь PySpark в Jupyter заметил в своём списке процессов какую-то джаву с токеном в открытом виде

```
> ps aux | grep spark

python ...

java -cp ... org.apache.spark.deploy.SparkSubmit
   --conf spark.yt.token=token ...
```

Прокидывание секретов

- ✓ Параметр скрыт в SparkUI
- Параметр скрыт в логах драйвера
- ✓ Параметр скрыт в ps на хосте запуска spark-submit
- 🗙 Параметр виден в ps при запуске PySpark

Что произошло?

• В коде для питона я прокидывала параметр при старте сессии

Что произошло?

- В коде для питона я прокидывала параметр при старте сессии
- Но в PySpark вызов getOrCreate запускает jvm c SparkSubmit

Что делать?

• У нас уже есть костыль в SparkSubmit, можем им воспользоваться

```
// example.py
os.environ["SPARK_YT_TOKEN"] = token
spark = SparkSession.builder.getOrCreate()
```

- ✓ Параметр скрыт в SparkUI
- Параметр скрыт в логах драйвера
- ✓ Параметр скрыт в ps на хосте запуска spark-submit
- ✓ Параметр скрыт в ps при запуске PySpark

Но в кластере на воркере...

• В списке процессов воркера, на котором запущен драйвер, видны все аргументы драйвера

```
> ps aux | grep spark

java -cp ... -Dspark.yt.token=token ...
org.apache.spark.deploy.worker.DriverWrapper ...
```

- ✓ Параметр скрыт в SparkUI
- Параметр скрыт в логах драйвера
- ✓ Параметр скрыт в ps на хосте запуска spark-submit
- ✓ Параметр скрыт в ps при запуске PySpark
- **Х** Параметр виден в ps на воркере в кластере

Что делать?

- Я добавила костыли
 - В запуск драйвера в SparkStandalone
 - В инициализацию SparkConf

- Параметр скрыт в SparkUI
- Параметр скрыт в логах драйвера
- ✓ Параметр скрыт в ps на хосте запуска spark-submit
- ✓ Параметр скрыт в ps при запуске PySpark
- Параметр скрыт в рѕ на воркере в кластере

Что делать?

• Не прокидывать секреты через конфиг спарка. Никогда. Даже если кажется, что это просто

• Использовать специальные сервисы для хранения секретов

Итоги

• Простое решение было сделано за 3 дня

• Рефакторинг на более сложное занял ещё несколько недель

• Чтение батчами ускорило запросы в 2-3 раза

В следующей серии...

- Pushdown predicate
- Оптимизация записи
- Использование информации о сортированности данных

• Гибкая интеграция с шедулером

Спасибо! Вопросы?